



9CFE-1908

Actas del Noveno Congreso Forestal Español
Edita: **Sociedad Española de Ciencias Forestales. 2025.**
ISBN: 978-84-941695-7-1



Limitaciones de la Transferibilidad de Modelos LÍDAR: caso práctico en el M.U.P. 141 “Montes Madres” de La Rioja

MARTÍN-ALCON, S. (1), NAVARRO, J.A. (1), CABRERA BONET, M. (2), BENGUA, D. (3), TOMÉ MORÁN, J.L. (1)

(1) Agresta Sociedad Cooperativa.

(2) Aranzada Gestión Forestal, S.L.P.

(3) Servicio de Gestión Forestal. Gobierno de la Rioja.

Resumen

El M.U.P. 141 “Montes Madres” (La Rioja), fue uno de los pioneros en incorporar tecnología LiDAR en los inventarios. Este estudio analiza las oportunidades y limitaciones de la transferencia de modelos LiDAR en un monte, donde actualmente existen cinco coberturas LIDAR entre 2009 y 2024. Esta disponibilidad de datos es una oportunidad tanto para estudiar la dinámica del monte en los últimos 15 años, como para actualizar los datos de inventario a partir de las parcelas existentes. El proyecto ha trabajado con la posibilidad de reutilizar datos de campo existentes y ajustar modelos transferibles al año actual con vuelos previos. Se emplearon diferentes fuentes de datos (parcelas la ordenación 2009 e IFN4) con sus correspondientes vuelos LiDAR, ajustando modelos que se han transferido calibrando los resultados con parcelas actuales. Los resultados demuestran transferencia es viable si se seleccionan métricas robustas, lo que podría tener un impacto notable abaratando los trabajos de campo, uno de los principales costes de inventario. Sin embargo, requiere un análisis cuidadoso de la nube de puntos y la calibración con datos actuales para abordar las diferencias fenológicas y tecnológicas entre vuelos (presencia/ausencia de hoja, densidad de puntos, sensores) que afectan notablemente la precisión de los modelos.

Palabras clave

Inventario forestal, Laser escáner, Teledetección, Sentinel2.

1. Introducción

El MUP N° 141 “Montes Madres” del catálogo de utilidad pública de La Rioja, fue junto con algunos otros montes pioneros como el Pinar de Valsaín (ORTOÑO et al, 2013) o los montes de utilidad pública n.º 246 “Guerreado y Abejón”, n.º 253 “Revenge” y n.º 581 “El Carrascal” (CUASANTE y GARCÍA, 2009), uno de los primeros pilotos a la hora de aplicar la tecnología LiDAR por métodos de masa a partir de vuelos específicos en España.

De esta manera en 2009 con motivo de la quinta revisión del proyecto de ordenación, la empresa Blom España se encargó de coordinar el vuelo LiDAR sobre el Monte de U.P. 141 “Montes Madres” y desarrollar un inventario LiDAR que supuso un cambio de paradigma con respecto a los inventarios clásicos de las anteriores revisiones.




En los últimos quince años, la tecnología LiDAR se ha transferido completamente desde las universidades, centros de investigación y empresas hasta la sociedad general, y hoy día los inventarios LiDAR están incorporados operativamente en la gestión y planificación forestal (GÓMEZ, et al, 2019; RODRÍGUEZ, et al, 2014)

En 2023, con motivo de la sexta revisión del Monte, desde el Servicio de Gestión Forestal del Gobierno de la Rioja, se ve la oportunidad de volver a ejecutar un inventario LiDAR a partir de un vuelo específico, con doble objetivo: dar continuidad a la tecnología utilizada en la quinta revisión y testar el potencial de la transferibilidad de modelos entre distintos vuelos LiDAR de cara a una futura actualización de la aplicación ForestLiDARioja (TOMÉ et al, 2020) a partir de los datos de la tercera cobertura LiDAR PNOA, que acabaría volándose durante agosto de 2024 en toda la Región.

De esta manera, en el pliego de prescripciones técnicas de la licitación de la sexta revisión del monte MUP N° 141 “Montes Madres” no se prevé un inventario LiDAR al uso levantando un mínimo de 30 parcelas por estrato de cara a desarrollar modelos que permitan predecir resultados de inventario a partir de las relaciones campo-LiDAR. En su lugar, se propone una metodología de inventario orientada al ahorro de costes en la toma de datos de campo, en la que se prevé desarrollar modelos a partir de la información de las masas capturada en 2009 (parcelas de campo y datos del vuelo LiDAR) y transferirlos a 2023 previa calibración de los modelos en un pequeño set de parcelas de campo.

El presente artículo aborda los condicionantes y limitaciones que tiene la transferibilidad de modelos entre distintos vuelos LiDAR, un tema que va a resultar de enorme interés para el sector en los próximos años, dado que, a fecha del presente congreso forestal, ya debería estar prácticamente cerrada la tercera cobertura LiDAR a nivel nacional (GÁRRIDO et al, 2022). Tras más de diez años trabajando con LiDAR disponemos de amplias bases de datos de parcelas de una gran diversidad de tipos de masa y localizaciones, lo que junto a las parcelas del Inventario Nacional Forestal (FERNÁNDEZ-LANDA, et al 2017) supone una enorme oportunidad para reciclar datos de campo para nuevos inventarios LiDAR, siempre que este trabajo se realice con las debidas precauciones técnicas.





de la transferencia de modelos de inventario LIDAR entre vuelos, con objeto de visibilizar esta realidad de los inventarios LiDAR, y que estas limitaciones sean tenidas en cuenta en el diseño operativo de futuros inventarios aprovechando la disponibilidad de los vuelos de la tercera cobertura del PNOA.

Este objetivo se ha dividido en los siguientes objetivos específicos:

- Evaluar la viabilidad de transferir modelos LiDAR entre distintas coberturas temporales
- Identificar métricas LiDAR robustas y estables entre vuelos
- Diseñar y validar una metodología de calibración de modelos transferidos

3. Metodología

3.1 Área de estudio y estratificación para inventario

El área de estudio corresponde al Monte de utilidad pública nº 141 del catálogo de La Rioja “Montes Madres” perteneciente al Ayuntamiento de Villoslada de Cameros y situado en su término municipal, en el Camero Nuevo, en la vertiente norte del Sistema Ibérico, en la cuenca del río Iregua, tributaria al Ebro.

Las principales formaciones arboladas del monte son las masas de pino silvestre, haya y rebollo distribuidas tal como se puede ver en la figura 1.

3.2 Datos de campo

Como datos de campo se han utilizado los datos de las parcelas levantadas en la quinta revisión de la ordenación del monte, en concreto, se han ajustado modelos para el estrato de latizales y fustales de *P. sylvestris*, uniendo 82 parcelas correspondientes a los estratos I y II de la quinta revisión (superestrato I). Por su parte, para el estrato de fustales de hayedo se han utilizado 46 parcelas correspondientes al estrato III de la quinta revisión (superestrato III), todas ellas levantadas entre los años 2009 y 2010.

Tabla 2. Caracterización de las variables de las muestras de ajuste utilizadas

Ho (m)	Dg (cm)	N (pies/ha)	G (m2/ha)	VCC (m3/ha)
18,7	29,9	728,6	45,7	351,0
12,5	16,2	160,0	16,3	92,2
25,3	50,4	1980,0	77,8	678,8

Superestrato I (n=81). Fuente: campo 2009/10

2,5	5,7	365,6	11,9	109,0
<i>Superestrato III (n=47). Fuente: campo 2009/10</i>				
20,7	25,5	756,2	34,7	288,8
13,7	15,2	280,0	16,6	117,6
28,7	37,5	2340,0	52,9	540,9
4,0	5,4	378,6	8,4	100,8
<i>Superestrato IV (n=15). Fuente: IFN4 2011/12</i>				
14,2	32,7	412,5	32,6	205,0
6,6	23,6	56,8	2,5	8,3
18,3	46,2	1077,5	61,0	461,5
3,2	6,6	265,2	16,6	126,0
<i>Superestrato V (n=155). Fuente: IFN4 2011/12</i>				
11,4	17,8	1027,2	20,4	95,6
4,5	9,5	56,8	1,0	3,9
20,5	60,4	3310,4	85,7	348,0
3,3	6,9	693,1	11,0	55,6

Para el caso de los estratos de pinares de montaña (superestrato IV) y rebollo (superestrato V), estratos en los que no se desarrollaron modelos específicos LiDAR en la quinta revisión y por tanto carecían de parcelas levantadas en campo, ha sido necesario ajustar modelos utilizando en parcelas de campo del IFN4 (años 2011 y 2012), recolocadas automáticamente mediante técnicas desarrolladas por Agresta (FERNÁNDEZ-LANDA, et al 2017) basadas en la comparación de las alturas del modelo digital de superficies LiDAR y la distribución de alturas del arbolado capturada en campo para evitar los errores de posicionamiento derivados de la ausencia de GPS submétrico durante los trabajos de campo del IFN en La Rioja .

Para calibrar los resultados obtenidos una vez transferidos a 2024 se han levantado en campo parcelas de *P. sylvestris* (n=15) y de *F. sylvatica* (n=5).

Tabla 3. Caracterización de las variables de las muestras de calibración utilizadas

Ho (m)	Dg (cm)	N (pies/ha)	G (m2/ha)	VCC (m3/ha)
<i>Superestrato I (n=15). Fuente: campo 2024</i>				

22,5	34,5	488,1	40,8	339,5
19,7	26,3	122,0	16,6	148,5
26,0	42,9	980,0	63,7	560,6
2,0	5,6	266,5	15,6	126,0
<i>Superestrato III (n=5). Fuente: campo 2024</i>				
27,5	33,9	445,6	34,9	342,7
20,1	26,4	171,0	25,3	181,7
34,1	44,9	833,0	45,5	554,9
5,6	6,9	258,0	9,8	138,0

Por último, para garantizar un buen funcionamiento del modelo en la especie de mayor importancia económica en el monte, *P. sylvestris*, se han levantado otras 10 parcelas orientadas a realizar una validación independiente de los modelos realizados para este superestrato.

Tabla 4. Caracterización de las variables de la muestra de validación independiente para pino silvestre

Ho (m)	Dg (cm)	N (pies/ha)	G (m2/ha)	VCC (m3/ha)
<i>Superestrato I (n=10). Fuente: campo 2024</i>				
19,4	32,8	402,8	35,2	251,1
18,5	10,0	75,1	22,9	78,9
20,5	65,6	950,6	49,6	491,9
0,6	15,9	261,4	7,9	119,7

Todas las parcelas de campo se han cubicado con los modelos desarrollados por el INIA que está usando el Servicio de Gestión Forestal. Gobierno de la Rioja para comercializar la madera:

- Sylvestre: $VCC = 0,0762 * (Dn)^{1,87} * (Ht)^{0,88}$
- Sylvestre Montaña: Ecuaciones IFN para la provincia de la Rioja.
- Haya: $Vt = 0,000301 * (Dn)^{1,71664} * (Ht)^{1,14314}$
- Rebollo: $Vt = 0,078078 * (Dn)^{1,833610} * (Ht)^{0,894805}$.

3.3 Datos LiDAR

Actualmente, tenemos hasta cinco coberturas disponibles: dos vuelos específicos para el inventario en el MUP N° 141 “Montes Madres” (el vuelo realizado para la quinta revisión en el 2009 y el vuelo realizado para la sexta revisión en el 2023) y tres coberturas del Plan Nacional de Ortofotografía Aérea (PNOA) voladas en los años 2010, 2016 y 2024. La tercera cobertura PNOA no estaba disponible a fecha de la redacción de la sexta ordenación por lo que no se utilizó como fuente de datos para el inventario.

En la tabla 5 se pueden apreciar los principales parámetros de los vuelos disponibles para el MUP N° 141 “Montes Madres”:

Tabla 5. Información detallada de los vuelos disponibles

Id Lote	Fecha Vuelo	Densidad	RMSE_Z	Sensor
2009 5ª rev.	19 noviembre 2009	2 pulsos/m ²	30 cm	Airborne Laser Terrain Mapper Gemini
2010 PNOA	CYL-RIO	Agosto-octubre 2010	0,5 pulsos/m ²	30 cm LEICA ALS50
2016 PNOA	Agosto-septiembre 2016	2 pulsos/m ²	30 cm	LEICA ALS80
2023 6ª rev.	28 de marzo 2023	8 pulsos/m ²	30 cm	ATLM Galaxy T2000 de Optech
2024 PNOA	Julio-septiembre 2024	5 pulsos/m ²	10 cm	ATLM Galaxy T2000 de Optech

Tal como se puede apreciar, estos vuelos tienen diferentes características en cuanto a densidades, sensores con tecnologías diferentes que han ido modernizándose con los años y fechas de captura, lo que tiene un especial impacto, puesto que tenemos algunos vuelos con hoja (coberturas PNOA) y otros sin hoja (vuelo de 2023) y lo que es más complejo, un vuelo de otoño en el 2009 en el que las frondosas estaban perdiendo la hoja, pero de manera parcial.

3.4 Procesado LiDAR y Modelización

La parte más compleja de la modelización en este tipo de estudios donde manejamos modelos desarrollados a partir de una base de datos LiDAR con unas características determinadas y la trasladamos a otro vuelo con características diferentes es garantizar una buena transferibilidad de modelos.

Hay dos situaciones comunes a este trabajo en las que se evalúa la transferibilidad de modelos: (i) cuando se aplican a nuevos datos recopilados en la misma área en un momento diferente (transferencia temporal), como es el caso del uso de la base de datos de la quinta revisión para transferir modelos al vuelo actual y (ii) cuando se entrenan con datos de una ubicación y se aplican en otra diferente (transferencia espacial) como es el caso de la base de datos del IFN4 en La Rioja, transferida al MUP N° 141 “Montes Madres”.



En los últimos años, la transferibilidad temporal de modelos ha sido estudiada por algunos autores (NAVARRO et al., 2020), habiéndose demostrado una buena transferibilidad entre nubes de puntos para los percentiles más altos (por encima del 75%), siendo recomendable en la medida de lo posible evitar las métricas de dispersión de alturas, con menores correlaciones una vez trasferidos los modelos (FILIPPELLI et al., 2019).

Por lo tanto, cuando trabajamos con transferencia de modelos, no debemos centrarnos únicamente en evaluar cómo de bien se comportan los modelos en los datos de ajuste, sino en cómo de bien transfieren esos modelos a las condiciones del vuelo hacia el que estamos transfiriendo, en este caso, un vuelo de invierno en el que las masas de frondosas se encuentran sin hoja. Por el contrario, los vuelos a partir de los cuales vamos a trasferir los modelos (vuelo propio de 2009 para el haya y los pinares, y vuelo de primera cobertura PNOA para el rebollo y pinares de montaña), se ejecutaron en fechas en las que las frondosas se encontraban parcial y totalmente con hoja respectivamente. Por otro lado, independientemente de las fechas de vuelo, para garantizar la transferibilidad de los modelos, es crucial que los datos utilizados para el ajuste de modelos abarquen toda variabilidad estructural de los estratos a caracterizar sobre en el inventario actual con el vuelo actualizado.

De cara a verificar el comportamiento de las nubes de puntos LiDAR se ha hecho un análisis completo de las mismas para comprender las semejanzas y diferencias entre ellas, y tratar de hallar las métricas más robustas que puedan ser utilizadas indistintamente en cada fuente de datos.

Con el objetivo de realizar una comparativa de tres sets de datos LiDAR utilizados (LiDAR 2009, LIDAR 2016 PNOA y LIDAR 2023), se ha realizado un procesado totalmente equivalente de los mismos. Todo el procesado LiDAR se realiza utilizando R versión 4.3.0 (R Development Core Team, 2023) mediante desarrollos de software propios de Agresta S. Coop. y trabajando sobre el paquete LidR (Roussel et al., 2020). La visualización de resultados se ha realizado tanto en R como en el sistema de información geográfica QGIS (QGIS.org, 2024).

Previamente al procesado de los vuelos fue necesario el filtrado y la reclasificación de la nube de puntos LiDAR 2009 que no estaba clasificada para lo que se utilizó la herramienta Lasground del software LAStools. Una vez hecho esto se procesaron los tres vuelos LiDAR generando Modelos Digitales de Elevaciones a partir de los puntos clasificados como suelo, lo que permite normalizar las alturas de los puntos clasificados como vegetación sobre el suelo. A partir de esta información se ha generado una batería de 70 estadísticos relativos a la distribución de las nubes de puntos por encima de 2 m para evitar los retornos correspondientes al matorral, utilizando un tamaño de celda de 20x20 m. En el procesado se han descartado aquellos puntos cuya altura esta por encima de una altura de seguridad superior a la altura máxima de los pies medidos en el monte (45 m) sobre el suelo, de cara a eliminar posibles puntos de ruido que no correspondan al arbolado. Posteriormente estas bases de datos georeferenciadas se han convertido en capas en formato ráster y vectorial para permitir su análisis

espacial.




Figura 2. Ejemplo de aplicación de la prueba de suma de rangos de Wilcoxon a pares de variables de los datos LiDAR de 2009 (en azul) y 2023 (en verde) para algunos estadísticos (Z95: percentil 95, zcum1 a zcum7 porcentaje de retornos acumulados por encima de 1 a 7 m FCC: Fracción de cabida cubierta) del estrato de hayedo.

Se ha realizado un análisis comparativo entre las nubes de 2009 y 2016 y las de 2009 y 2023 en búsqueda de variables robustas y estables. Para hallar variables equivalentes se utilizó la prueba de suma de rangos de Wilcoxon (Figura 2) por pares con un nivel de significación de 0,05. Esta es una prueba estadística no paramétrica utilizada para comparar dos muestras relacionadas y determinar si provienen de la misma distribución poblacional. En el contexto de búsqueda de variables equivalentes entre dos fuentes de datos, se utiliza para evaluar si las distribuciones de las variables en ambas fuentes son estadísticamente similares o equivalentes. Si la prueba muestra que no hay una diferencia significativa entre las variables, se consideran equivalentes en términos de su distribución en las dos fuentes de datos. Esto sugiere que las variables podrían utilizarse de manera intercambiable en análisis posteriores sin introducir sesgos debido a diferencias sistemáticas entre las fuentes de datos.

Por otro lado, se ha hecho un análisis de variables equivalentes en las distintas nubes de puntos mediante diagramas de dispersión. Estos diagramas nos han permitido visualizar de forma directa la relación entre los pares de variables entre

vuelos y compararlas de cara a ver si existen desviaciones significativas o no para fortalecer la transferibilidad de los modelos.




Figura 3. Ejemplo de diagrama de dispersión de pares de variables en los datos LiDAR de 2009 y 2023.

El resultado de estos análisis indica que los modelos desarrollados utilizando datos de 2009 son transferibles a la nueva nube de puntos de 2023 gracias al método de selección de variables estables. El análisis de métricas LiDAR sugiere que las variables relacionadas directamente con la altura de la vegetación son más estables que las variables de dispersión de altura y cobertura, y que, concretamente, los percentiles altos de altura se comportan de forma más robusta que los percentiles bajos. En el caso del haya y el rebollo hay que tener especial cuidado con las variables de cobertura, dado que el vuelo de 2023 es sin hoja, con lo que existe una diferencia muy importante de la fracción de cabida cubierta entre vuelos (ver figura 2). Este problema se ha abordado mediante dos soluciones diferenciadas en cada caso. En el caso del superestrato de hayedos, al disponer de un set de parcelas de calibración medidas en 2023 sobre el que se han calculado las métricas correspondientes al vuelo LiDAR de 2023, se han podido calibrar los modelos ajustados con los datos de 2009/10 a las características específicas del vuelo de 2023. En el caso del superestrato de rebollar, al no existir un set de parcelas de calibración medidas en 2023, los modelos ajustados con IFN y LiDAR de



2010 se han aplicado sobre una combinación de métricas de 2016 (métricas de cobertura y dispersión) y 2023 (métricas de altura), con la finalidad de minimizar el efecto “sin hoja” del vuelo de 2023, y sabiendo que no han existido perturbaciones significativas en este estrato entre 2016 y 2023.

Para los distintos estratos se ajustaron modelos no paramétricos utilizando la metodología Random Forest (RF) (BREIMAN, 2001) con el paquete randomForest (LIAW & WIENER, 2002) en el software estadístico R (R Development Core Team, 2023) para las variables dasométricas objetivo: Altura dominante (Ho), Área basimétrica (G), Diámetro cuadrático medio (Dg), Volumen con corteza (VCC), y Número de pies (N). A pesar de ser un método estadístico que se comporta bien cuando existen un elevado número de variables predictoras, incluso con cierta autocorrelación, está demostrado que los resultados mejoran cuando se eliminan variables redundantes o correlacionadas. De esta manera se evita el sobreajuste y los modelos generados son más robustos. Para ello, se ha utilizado la metodología de selección optimizada de variables predictivas desarrollada en el paquete VSURF del software R (GEUNER et al., 2016).

Posteriormente, para los modelos de pino silvestre y haya se ha ajustado un segundo modelo (de calibración) para corregir posibles sesgos sistemáticos y ajustar el modelo principal a las características particulares de la nube de puntos de 2023. La metodología RF presenta una limitación bastante común en modelos de regresión de aprendizaje automático, que consiste en que éstos pueden ser propensos a devolver sesgos sistemáticos: los valores pequeños se sobreestiman y los valores grandes se subestiman. Esto es así porque el objetivo del modelo es reducir al máximo posible el RMSE, y como la mayor concentración de datos de ajuste suele darse en los rangos centrales de la variable observada, el modelo tiende a ajustar mejor en ese rango, “olvidando” o dando menos peso a los valores extremos (altos y bajos), pues al haber menos datos, tienen menos influencia en el RMSE. Existen diferentes métodos para corregir este sesgo (BELITZ & STACKELBERG, 2021). La implementada por Agresta es la conocida como ROE (*Regression of observed on estimated values*), complementada con una selección de covariables LiDAR que son seleccionadas en función de su significancia en el modelo de calibración. En definitiva, lo que se hace es ajustar un modelo lineal múltiple que además de los valores predichos por el modelo de RF, puede incluir algunas métricas LiDAR como covariables.

Este segundo modelo es el que se utiliza, además de para corregir el sesgo sistemático propio del modelo general de RF para ajustarlo a las características particulares del vuelo y/o zona de aplicación de los modelos. Para ello, el ajuste del modelo lineal múltiple se realiza únicamente con datos de la zona y/o vuelo de aplicación, produciendo así un conjunto de modelos (randomforest + modelo lineal) para cada estrato y variable dependiente.

De cara a seleccionar los mejores modelos posibles de todos aquellos que se ensayaron se utilizaron varios criterios para evaluar la bondad de ajuste de los modelos realizados: sesgo y error cuadrático medio (absolutos y relativos; PARRESOL, 1999). A la hora de la selección final de los modelos se seleccionaron

aquellos modelos que presentaban una menor combinación de sesgo y error cuadrático medio de entre todos los ajustados. Para ello se utilizó la muestra de calibración levantada en campo para los superestratos I (Pino Silvestre) y III (haya) (tablas 7 y 8), mientras que para los superestratos IV (Pinar de montaña) y V (rebollo) los modelos fueron seleccionados mediante validación cruzada de las parcelas de ajuste como promedio de 99 diferentes modelos ajustados con un 80 % de las parcelas de la muestra y validados sobre el 20 % de las parcelas restantes (tablas 9 y 10). En el caso del superestrato de pinar la bondad de ajuste se evaluó además sobre una muestra independiente de 10 parcelas (tabla 11).

De acuerdo a lo expuesto, se resume en la tabla 6 el esquema de modelización utilizado para cada superestrato, condicionado por la disponibilidad o no de datos de inventario en las diferentes anualidades, así como la mayor o menor afección de cada estrato por los estados fenológicos en el momento del vuelo.

Tabla 6. Información resumen del esquema de modelización y transferencia de modelos para cada superestrato

Superestrato	Datos ajuste	Datos calibración	Validación	Vuelo LiDAR de aplicación	Método de transferencia		
I (pinos)	Campo 2009/10	LiDAR 2009	Campo 2024	LiDAR 2023	Independiente	(datos 2024)	LiDAR 2023 Selección de variables transferibles y calibración con datos actuales
III (hayedos)	Campo 2009/10	LiDAR 2009	Campo 2024	LiDAR 2023	Muestra de calibración (datos 2024)	LiDAR 2023	Selección de variables transferibles y calibración con datos actuales
IV (pinos de montaña)	Campo IFN 2011/12	LiDAR 2010	Sin calibración	Validación cruzada en muestra de ajuste	LiDAR 2023	Selección de variables transferibles	
V (rebollares)	Campo IFN 2011/12	LiDAR 2010	Sin calibración	Validación cruzada en muestra de ajuste	Variables de cobertura LiDAR 2016 y variables de altura LiDAR 2023	Selección de variables transferibles	

4. Resultados

Como principales resultados del proyecto se presentan la bondad de ajuste de los modelos ajustados evaluada a través del sesgo y error cuadrático medio (absolutos y relativos) así como los gráficos de residuos del ajuste del modelo de volumen para todos los estratos (figuras 4, 5 y 6).

En las tablas 7 y 8 se pueden observar los resultados obtenidos sobre la muestra de calibración de parcelas de pino silvestre y haya.

Tabla 7. Resultados de calibración del estrato de pino silvestre (superestrato I)

Variable	sesgo	Sesgo (%)	RMSE	RMSE (%)
Ho (m)	-0,004	-0,016	1,35	6,05
Dg (cm)	-2,22	-6,47	4,96	14,45
N (pies/ha)	6,75	1,40	164,02	33,99
G (m ² /ha)	-0,14	-0,37	10,02	25,55
VCC (m ³ /ha)	-6,01	-1,86	72,21	22,31

Tabla 8. Resultados de calibración del estrato de haya (superestrato III)

Variable	sesgo	Sesgo (%)	RMSE	RMSE (%)
Ho (m)	0,22	0,80	2,61	9,49
Dg (cm)	-0,17	-0,49	5,40	15,94
N (pies/ha)	-30,87	-6,93	148,867	33,41
G (m ² /ha)	0,19	0,54	7,62	21,83
VCC (m ³ /ha)	0,45	0,13	57,22	16,70




Figura 4. Diagrama de residuos de la muestra de calibración del modelo para el volumen con corteza (VCC, m³/ha), a la izquierda de pino silvestre (superestrato I), a la derecha haya (superestrato III)

Para los modelos realizados sobre la muestra de parcelas del IFN4 no se ha hecho calibración con parcelas propias, por lo que se dan los resultados de validación cruzada como promedio de 99 diferentes modelos ajustados con un 80 % de las parcelas de la muestra y validados sobre el 20 % de las parcelas restantes:

Tabla 9. Resultados de validación cruzada del modelo de pinares de silvestre de alta montaña (superestrato IV)

Variable	sesgo	Sesgo (%)	RMSE	RMSE (%)
Ho (m)	0,081	0,58	1,06	7,59
Dg (cm)	0,65	2,09	6,07	18,70
N (pies/ha)	-1,54	-4,70	3,53	10,80
G (m ² /ha)	-0,03	-0,09	11,01	32,73
VCC (m ³ /ha)	7,26	3,73	67,49	33,89

Tabla 10. Resultados de validación cruzada del modelo de rebollo (superestrato V)

Variable	sesgo	Sesgo (%)	RMSE	RMSE (%)
Ho (m)	-0,002	-0,016	1,70	14,69
Dg (cm)	-0,001	-0,008	6,51	36,44
N (pies/ha)	-0,35	-1,94	4,77	26,82
G (m ² /ha)	-0,18	-0,82	7,99	39,42
VCC (m ³ /ha)	-1,49	-1,34	34,30	36,02




Figura 5. Diagrama de residuos de la muestra de calibración del modelo para el volumen con corteza (VCC, m³/ha), a la izquierda de pino silvestre de montaña (superestrato IV), a la derecha rebollo (superestrato V)

De cara a garantizar el buen funcionamiento del modelo sobre pino silvestre se ha levantado una muestra independiente de 10 parcelas sobre las que testar el



modelo desarrollado. Los resultados de la citada validación se pueden apreciar tanto en la tabla 7 que muestra la bondad de ajuste de los modelos como en la como en la figura 4 que nos muestran un ejemplo del gráfico de residuos para el volumen con corteza comparando los datos observados con los predichos. Tal como se puede apreciar, los resultados de la muestra de validación independientes tienen valores en el mismo orden de magnitud que los de la muestra de calibración, por ejemplo, el RMSE relativo del volumen con corteza pasa de 22,31 % al 25,21 %.

Tabla 11. Resultados de validación independiente del modelo de pino silvestre (superestrato I)



Variable	sesgo	Sesgo (%)	RMSE	RMSE (%)
Ho (m)	-0,24	-1,17	1,77	8,57
Dg (cm)	-3,80	-10,82	8,44	23,97
N (pies/ha)	2,59	0,64	165,55	41,10
G (m²/ha)	0,71	2,19	8,76	26,70
VCC (m³/ha)	3,06	1,22	63,31	25,21




Figura 6. Diagrama de residuos de la muestra de validación independiente del modelo de pino silvestre (superestrato I) para el volumen con corteza (VCC, m³/ha)
En la figura 7 podemos apreciar los resultados del inventario LiDAR de la sexta revisión del monte, tanto a nivel de celdas como a nivel de los cuarteles del monte.




Figura 7. Resultados de inventario para el volumen con corteza (VCC, m³/ha), a la izquierda resultados por celdas (20x20 m), a la derecha resultados por cantón.



Aplicando al vuelo LiDAR de la quinta revisión los modelos ajustados, podemos comparar los resultados para cada uno de los principales estratos presentes en el monte entre 2009 y 2024, tal como se puede ver en la tabla 12.

Tabla 12. Comparación de existencias por estratos arbolados entre la quinta y la sexta revisión



Estrato / Revisión	Sup. (ha)	Ho	(m)	Dg	(cm)	N	(Pies/ha)	G	(m²/ha)	VCC (m³/ha)
Pino silvestre 5 Revisión	3.142,84	17,3	31,95	492,27	38,07			293,82		
Pino silvestre 6 Revisión	3.138,03	20,28	31,42	446,98	34,51			269,56		
Haya 5 Revisión	1.366,99	20,3	31,35	422,58	29,68			184,44		
Haya 6 Revisión	1.366,76	22,02	31,65	411,13	30,33			227,31		
Pino silvestre alta montaña 5 Revisión	758,96	10,16	29,5	330,29	19,23			99,97		
Pino silvestre alta montaña 6 Revisión	768,31	12,19	31,92	274,62	20,83			135,30		
Rebollo 5 Revisión	1.226,16	10,61	18,76	507,02	13,28			57,88		
Rebollo 6 Revisión	1.206,08	12,06	19,65	629,99	17,52			82,12		

5. Discusión

Si bien los modelos finalmente ajustados con los datos de inventario de 2009/10 — en el caso de los superestratos I y III—, o de 2011/12 —en el de los superestratos IV y V—, podrían no ser los mejores modelos posibles en caso de haber utilizado todas las métricas LiDAR disponibles como variables candidatas a explicativas, los resultados nos muestran que con la disminución de precisión de los modelos debido a la preselección de métricas más transferibles, estos siguen quedando dentro del rango de errores que habitualmente han obtenido otros autores en inventarios LiDAR por métodos de masa, incluso en el caso de inventarios directos (sin transferencia espacial ni temporal).

DOMINGO y colaboradores (2019) obtuvieron valores RMSE relativo en transferencia de modelos de pino carrasco (Ho: 8,54%; Dg: 15,35%; N: 42,43%; G: 25,5% y VCC: 20,9%) trabajando con modelos de *support vector machine* (SVN) en validación cruzada. Valores que están en el mismo orden de magnitud de los que obtuvimos en el presente trabajo para nuestra muestra independiente de pino silvestre trabajando con RF (Ho₂₀₂₄: 8,57%; Dg₂₀₂₄: 23,97%; N₂₀₂₄: 41,10%; G₂₀₂₄: 26,7% y VCC₂₀₂₄: 25,2%).

FERNÁNDEZ-LANDA y colaboradores (2017) trabajando con modelos lineales generalizados (GLM) ajustados para el vuelo de PNOA 2010 a partir de parcelas del IFN4 recolocadas manualmente en La Rioja obtuvieron valores mejores de RMSE relativo para área basimétrica (G: 8,8 %) equivalentes para volumen (VCC: 26,1 %) y peores para densidad (N: 50,3 %) validación independiente sobre el estrato de pino silvestre. Trabajando sobre haya los resultados estuvieron también dentro del mismo orden de magnitud (N: 44,0%; G: 21,5% y VCC: 24,5%). que los obtenidos en nuestra muestra de calibración (N₂₀₂₄: 33,41%; G₂₀₂₄: 21,83% y VCC₂₀₂₄: 16,7%).

FEKETY y colaboradores (2018) exploraron la transferencia de modelos a través de la predicción de atributos forestales en ubicaciones que no estaban representadas en los datos de entrenamiento mediante la combinación de mediciones LiDAR y de campo provenientes de bosques ecológicamente similares. Para ello combinaron seis colecciones de datos LiDAR con diferentes parámetros de adquisición con sus respectivas muestras de campo, y probaron a modelizar cada una de ellas con las cinco localizaciones ecológicamente similares utilizando RF y buscando equivalencias entre las nubes de puntos. Sus resultados resultaron peores que los nuestros con RMSE relativos de entre 32,3 % y 50,1 % para el área basimétrica y de entre el 40,7% y el 67 % para el número de pies, concluyendo que, si bien se pueden utilizar modelos predictivos construidos a partir de bosques ecológicamente similares para obtener una estimación preliminar de los recursos, conviene hacer trabajo de campo para mejorar las precisiones obtenidas.

SUMNALL y sus colaboradores en 2024 trabajando plantaciones de *Pinus taeda* y *Pinus elliottii* en el sur de EE.UU. con modelos de regresión lineal múltiple y Random Forest, observaron que los modelos de volumen fustal podían transferirse



con un descenso moderado en la precisión (RMSEr 10–16%) siempre que tanto condiciones estructurales de las masas y su manejo sean equivalentes a las de la muestra de ajuste. Sin embargo, cuando se incrementaban las diferencias estructurales ya sea por edad o por tratamientos selvícolas en las masas a las que se pretende transferir el modelo, dando lugar a estructuras no muestreadas en las masas de ajuste, la precisión se reducía significativamente hasta un 16 % en volumen y un 40 % en área basimétrica con respecto a los modelos transferidos a masas con estructuras equivalentes. Estos resultados demuestran la importancia de recoger toda la variabilidad estructural del estrato en la muestra de ajuste y coinciden con los obtenidos en este estudio, donde la evolución tecnológica de los sensores y, especialmente, las diferencias de las nubes de punto derivadas del momento fenológico de las masas de frondosas entre vuelos (hoja frente a sin hoja) han demostrado ser factores críticos para la transferibilidad.

DOMINGO et al. (2019), por su parte, utilizaron un enfoque directo e indirecto para evaluar la transferencia temporal de modelos forestales utilizando datos LiDAR de baja densidad. Sus resultados coincidieron con los nuestros en el sentido de la importancia de analizar los datos de entrada y las variables seleccionadas. Sin embargo, Domingo y sus colaboradores demuestran que con una mayor densidad de puntos LiDAR mejora la precisión del modelo, mientras que nuestro análisis apunta a un menor efecto de la densidad en sí misma, y siendo más determinante la existencia de similitudes entre las estructuras de las nubes de puntos.

El desarrollo de modelos LiDAR partiendo de bases de datos existentes y su transferencia a nuevos vuelos tales como los de la tercera cobertura LiDAR PNOA, que va a estar disponible en los próximos años a nivel nacional, puede ser una oportunidad para aprovechar los datos de campo ya capturados y abaratar lo que supone uno de los costes más importantes en los inventarios forestales (NAVARRO, 2019, TOMÉ et al, 2022). No obstante, nuestro trabajo ilustra algunas de las dificultades que pueden aparecer en este proceso, y constata que para poder aprovechar estos datos es imprescindible tener un adecuado conocimiento de las nubes de puntos entre las que estamos haciendo la transferencia de modelos, una transferencia que generalmente será tanto temporal como espacial (TOMPALSKI et al 2019, NAVARRO et al, 2020; MARINO, 2022; EASTBURN, 2024).

6. Conclusiones

Los resultados obtenidos para el MUP N° 141 “Montes Madres” demuestran que la transferibilidad de modelos LiDAR es una herramienta prometedora para la actualización de inventarios forestales, permitiendo el aprovechamiento de datos históricos. Sin embargo, queda patente que el uso de modelos desarrollados a partir de otras nubes de puntos sin tener en cuenta las limitaciones de la tecnología puede llevar a errores de bulto en inventarios forestales.

Las diferencias fenológicas de la vegetación entre vuelos (por ejemplo, presencia o ausencia de hoja) y la evolución tecnológica de los sensores LiDAR afectan la penetración del pulso en la vegetación y por tanto a la distribución de las métricas derivadas de las nubes de puntos y a la precisión de los modelos transferidos. Estos



factores deben tenerse siempre en cuenta a la hora de diseñar un inventario partiendo de bases de datos que impliquen transferibilidad temporal o espacial.

La eficacia de esta transferencia de modelos depende en gran medida de la selección de métricas robustas y estables, particularmente aquellas relacionadas con la altura dominante y los percentiles altos, que deben complementarse con aquellas métricas de cobertura o dispersión que ofrezcan mayores equivalencias entre vuelos.

Con objeto de garantizar aplicabilidad de los modelos transferidos, es fundamental que las bases de datos utilizadas sean representativas de variabilidad estructural de las masas que se pretenden inventariar. Además, resulta recomendable levantar un set de parcelas de calibración en campo, que nos permitan mejorar la precisión del modelo general y verificar que la transferencia entre las masas es adecuada.

De cara a aprovechar todo el potencial de transferencia de modelos LiDAR es necesario que se siga profundizando en este campo, en este sentido sería interesante trabajar con inteligencia artificial avanzada como aprendizaje profundo (*Deep learning*), así como ampliando las muestras de validación de modelos mediante parcelas independientes en distintas especies y estructuras forestales.

7. Agradecimientos

Los autores agradecen la colaboración de Felix Pinillos asistencia técnica de TRAGSATEC para Servicio de Gestión Forestal. Gobierno de la Rioja durante todo el proceso de mejora de los resultados del inventario forestal de la sexta revisión, así como el apoyo de la guardería responsable del MUP N° 141 “Montes Madres” del catálogo de utilidad pública de La Rioja en los trabajos de campo de informe selvícola y levantamiento de las parcelas de validación independiente.

8. Bibliografía

BELITZ, K., & STACKELBERG, P. E. 2021. Evaluation of six methods for correcting bias in estimates from ensemble tree machine learning regression models. *Environmental Modelling & Software*, 139, 105006.

BREIMAN, L.; 2001. Random Forests. *Machine Learning*, DOI-10.1023/A:1010933404324, 45(1): 5-32. Disponible en: <http://dx.doi.org/10.1023/A%3A1010933404324>.

CUASANTE, D.; GARCÍA C.; 2009. Estimación de recursos forestales con tecnología LIDAR aerotransportada. Aplicación práctica en varios montes de la Provincia de Burgos. En: *Actas del 5º Congreso Forestal Español. Volumen 1*. REF.: 5CFE01-544. S.E.C.F.; Junta de Castilla y León.



DOMINGO, D.; ALONSO, R.; LAMELAS, M.T.; MONTEALEGRE, A.L.; RODRÍGUEZ, F.; DE LA RIVA, J. 2019. Temporal Transferability of Pine Forest Attributes Modeling Using Low-Density Airborne Laser Scanning Data. *Remote Sens.* 11, 261. <https://doi.org/10.3390/rs11030261>.

EASTBURN, J.F.; CAMPBELL, M.J.; DENNISON, P.E.; WILLIAM R.; BARRETT, K.J.; FEKETY, P.A.; FLAKE, S.W.; HUFFMAN, D.W.; KANNENBERG, S.A.; KERR, K.L.; SÁNCHEZ, A.J. & VOGELER J.C. 2024. Ecological and climatic transferability of airborne lidar-driven aboveground biomass models in Piñon-Juniper woodlands, *GIScience & Remote Sensing*, 61:1, 2363577, DOI: 10.1080/15481603.2024.2363577
FEKETY, PATRICK A.; FALKOWSKI, MICHAEL J.; HUDAK, ANDREW T.; JAIN, THERESA B.; EVANS, JEFFREY S. 2018. Transferability of lidar-derived basal area and stem density models within a northern Idaho ecoregion. *Canadian Journal of Remote Sensing*. 44(2): 131-143.

FERNANDEZ-LANDA, A., TOMÉ, J.L., SANDOVAL, V., VALLEJO, R. 2017. Integrando datos LiDAR, información satelital y parcelas del Inventario Forestal Nacional español en la predicción de variables de inventario. 7º CFE, Plasencia.
FILIPPELLI, S.K.; LEFSKY, M.A.; ROCCA, M.E. 2019. Comparison and integration of LiDAR and photogrammetric point clouds for mapping pre-fire forest structure. *Rem. Sens. Envi.*, 224 (2019), pp. 154-166,

GARRIDO-SÁENZ DE TEJADA, J.M., GUTIÉRREZ-RICO, B., FERNÁNDEZ-RENAU GONZÁLEZ-ANLEO, A. 2022. PNOA-LiDAR 3ª cobertura. En *Teledetección para una Agricultura Sostenible en la era del Big Data*, Actas del XIX Congreso de la Asociación Española de Teledetección, pp. 181-184. Pamplona.

GENUER, R.; POGGI, J.-M.; TULEAU-MALOT, C.; 2016. Variable selection using Random Forests. *Pattern Recognition Letters*, 31(14): 2225-2236, 2016.

GÓMEZ, C., ALEJANDRO, P., HERMOSILLA, T., MONTES, F., PASCUAL, C., RUIZ, L. A., ÁLVAREZ-TABOADA, F., TANASE, M., & VALBUENA, R. 2019. Remote sensing for the Spanish forests in the 21st century: a review of advances, needs, and opportunities. *Forest Systems*, 28(1), eR001. <https://doi.org/10.5424/fs/2019281-14221>

LIAW, A.; WIENER, M.; 2002. Classification and Regression by randomForest. *R News*, 2(3): 18-22.

MARINO, E.; TOMÉ, J.L.; HERNANDO, C.; GUIJARRO, M.; MADRIGAL, J. 2025. Transferability of Airborne LiDAR Data for Canopy Fuel Mapping: 2022. Effect of Pulse Density and Model Formulation. *Fire*, 5, 126. <https://doi.org/10.3390/fire5050126>

NAVARRO, J.A. 2019. Aplicaciones de la fotogrametría digital aérea en el inventario forestal. Universidad Politécnica de Madrid. 152 pp.



NAVARRO, J.A.; TOMÉ, J.L.; MARINO, E.; GUILLÉN-CLIMENT, M.L.; FERNÁNDEZ-LANDA, ALFREDO.2020. Assessing the transferability of airborne laser scanning and digital aerial photogrammetry derived growing stock volume models. *International Journal of Applied Earth Observation and Geoinformation*, Volume 91, 102135, ISSN 0303-2434.

ORTUÑO PEREZ, SIGFREDO FCO., NÚÑEZ MARTÍ, MARÍA VICTORIA, MAURO, F., GAMAZO, M. V, MARTÍN FERNÁNDEZ, S. AND GARCÍA ABRIL, ANTONIO DAMIÁN 2013. Estimación de los costes de inventario forestal con y sin información LIDAR. En: "Montes: Servicios y desarrollo rural", 10/06/2013 - 14/06/2013, Vitoria- Gasteiz. pp. 1-10.

PARRESOL, B.R., 1999. Assessing tree and stand biomass: a review with examples and critical comparisons. *Forest Science*, 45(4): 573–593.

R DEVELOPMENT CORE TEAM; 2014. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria.

RODRIGUEZ, F.; FERNANDEZ-LANDA, A.; TOME, J. 2014. Resultados y reflexiones tras cinco años de inventario forestal con tecnología LiDAR. *Foresta* 61: 28-33

ROUSSEL, J-R.; AUTY, D.; COOPS, N.; TOMPALSKI, P.; GOODBODY, T.R.H.; MEADOR A.S.; BOURDON J-F.; BOISSIEU, F.; ACHIM, A. 2020. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, Volume 251, 112061, ISSN 0034-4257

SUMNALL, M. J., CARTER, D. R., ALBAUGH, T. J., PLATT, E., HOST, T., COOK, R. L., & RUBILAR, R. A.2024. Evaluating the transferability of airborne laser scanning derived stem size prediction models for *Pinus taeda* L. stem size estimation to two different locations and acquisition specifications. *International Journal of Remote Sensing*, 45(16), 5267–5294. <https://doi.org/10.1080/01431161.2024.2370499>

TOMÉ, J. L.; SOTO, M.; CRESPO, O.; GARCIA, A. D.; 2020. Forest LidaRioja, actualización y puesta en valor de la información forestal obtenida a partir de sensores remotos. *Revista Montes*, 140: 29-34.

TOMÉ, J. L., MARTÍN-ALCÓN, S.; TORAÑO, A.; OLIVAR, J.; UHL, E.; NAVARRO, J.A.; PRETZSCH; H. 2022. Inventario por transferencia de modelos LiDAR a nubes de puntos fotogramétricas en masas de píceas en Traunstein Alemania. *Actas del XIX Congreso de la Asociación Española de Teledetección: Teledetección para una agricultura sostenible en la era del big data*, pp. 185-188. 2022, Pamplona.

TOMPALSKI, P; WHITE, C. COOPS, N., WULDER M.A. 2019. Demonstrating the



transferability of forest inventory attribute models derived using airborne laser scanning data, Remote Sensing of Environment. Volume 227, Pages 110-124.
<https://doi.org/10.1016/j.rse.2019.04.006>